

基于宽度学习和注意力机制的小样本通信辐射源个体识别方法

陈宇鹏¹, 刘辉¹, 任高星², 杨俊安¹

(1. 国防科技大学电子对抗学院, 合肥 230037; 2. 31683 部队, 兰州 730000)

摘要: 在小样本通信辐射源个体识别场景中, 现有深度学习算法对通信辐射源个体特征提取困难, 识别率不高。针对此问题, 本文提出通过融合注意力机制和宽度学习构建浅层神经网络的识别方法。首先, 引入宽度学习来简化网络模型, 减轻小样本带来的过拟合现象; 其次, 构建节点注意力模块提高宽度神经网络在小样本条件下特征提取能力; 最后, 在公开数据集上验证提出方法的有效性。结果表明, 在少量样本条件下相比深度学习方法, 本文提出的方法改善了深度学习网络的过拟合现象, 加强了宽度学习方法的特征提取能力, 提高了识别准确率。

关键词: 小样本; 辐射源个体识别; 注意力机制; 宽度学习

中图分类号: TN911.7; TP18

文献标志码: A

Few-Shot Specific Communication Emitter Identification Method Based on Broad Learning and Attention Mechanism

CHEN Yupeng¹, LIU Hui¹, REN Gaoxing², YANG Junan¹

(1. College of electronic countermeasures, National University of Defense Technology, Hefei 230037, China; 2. Unit 31683, Lanzhou 730000, China)

Abstract: Under the condition of few-shot specific communication emitter identification, the difficulty of extracting individual features of communication radiation source by the existing deep learning algorithm increases, and the recognition rate decreases. To solve this problem, this paper proposes a recognition method to construct a shallow neural network by fusing attention mechanism and broad learning. Firstly, broad learning is introduced to simplify the network model and reduce the overfitting phenomenon caused by small samples; secondly, the node attention module is constructed to improve the feature extraction ability of the broad neural network under the condition of small samples; and finally, the effectiveness of the proposed method is verified on the public dataset. The results show that compared with the deep learning method with a small number of samples, the proposed method improves the overfitting phenomenon of the deep learning network, strengthens the feature extraction ability of the broad learning method, and improves the recognition accuracy.

Keywords: few-shot; specific emitter identification; attention mechanism; broad learning

引言

辐射源个体识别 (Specific Emitter Identification, SEI) 是指通过接收辐射源发射的无线信号, 提取辐射源硬件固有特征属性确定辐射源个体。对于通信辐射源个体识别, 由于生产工艺的限制, 通信辐射源硬件的实际性能参数与额定参数间存在细微差异, 使得其具有个体属性特征。这种个体属性特征被称为射频指纹特征, 难以伪造, 且与通信信号承载的信息内容相互独立, 是通信辐射源个

体识别技术的理论依据,在目标识别、电磁态势感知等领域具有重要作用^[1]。

随着人工智能的发展,基于机器学习通过数据驱动的通信辐射源个体识别方法有了广泛应用,其中基于深度学习的方法能够从大量数据中自动学习出通信辐射源个体区分能力较强的射频指纹特征,对通信辐射源个体的属性特征具有更好的信息表征能力。主流的深度学习神经网络包括卷积神经网络^[2]、循环神经网络^[3]和生成对抗网络^[4]等,利用其各自的网络特性在通信辐射源识别上取得了较好的分类效果。以上深度学习神经网络的较好表现是基于训练数据完备的情况,但在实际应用的非合作场景下,我们很难获得充足高质量的数据样本。而神经网络的学习过程可以看作神经网络模型对输入个体电台数据的拟合过程。在输入样本数据量小时,输入样本对个体电台特征代表性不足,对个体电台指纹的指纹特征描述不充分,会导致神经网络拟合的个体模型与实际模型偏差较大。因此,在小样本条件下的如何训练得到鲁棒的深度学习神经网络是当前通信辐射源个体识别领域的难点。

小样本学习问题从形成机理来看是由于训练样本数据的不完备导致神经网络对样本特征提取过拟合。当前对小样本学习问题的解决方法大致可以分为三种:基于模型微调、基于数据增强和基于高效学习的方法^[5]。

基于模型微调^[6]的方法通常在源域数据集上预训练模型,在目标域数据集上进行参数微调。但目标域数据和源域数据存在显著差异时,容易导致模型在目标域数据上过拟合,且在没有充足训练数据情况下无法预训练。

数据增强是指扩充现有信号样本数量以拓展非指纹特征的多样性^[7]。具体是通过加噪、移相、翻转等方法增加数据量。该方法着眼于通过增加训练样本的规模提升模型识别精度,实现简单,但是没有建立数据增强方法与信号指纹特征的直接联系,缺乏物理层面上的可解释性,增强后信号指纹特征可能完备性提高不多甚至被损坏。

高效学习如度量学习^[8]通过学习数据间的分布差异、元学习^[9]通过利用过去的知识和经验帮助模型在小样本条件下更好地理解数据中潜在的模式和关系。该方法对目标函数的构造极为敏感,不恰当的目标函数构造会导致模型性能提升有限,甚至出现局部最优的问题。

以上三种方法主要聚焦于改善神经网络模型对小样本个体指纹特征的提取性能,忽略了模型复杂度对小样本条件的影响。在小样本条件下,输入数据对个体指纹特征描述不充分,深度学习方法模型复杂,更容易在训练数据上学习到噪声和特定的特征,导致模型的泛化能力差。陈^[10-11]等提出的宽度学习(Broad Learning, BL)可以解决深度学习遇到的上述问题。宽度学习简单的模型结构提高了模型的泛化能力,并通过求解伪逆更新权重的方式避免了梯度消失和梯度爆炸问题,在小样本条件下比深度学习的方法可以做到兼顾更好的特征表达能力和更快的反应时间。随着对宽度学习研究的深入,基于宽度学习的通信辐射源个体识别方法也相继被提出。文献[12]提出了一种自适应宽度学习方法来构建轻量级 SEI 模型。设计了一种自适应节点展开策略,快速获得模型的最优超参数。文献[13]在预处理阶段设计了一种分层混合采样方法,以改善数据分布的不平衡,重建指纹数据集。文献[14]提出了一种使用信号特征嵌入式宽度学习网络的 SEI 方法。该方法先通过外部信号处理节点对原始射频数据进行预处理。其次,设计内部信号处理节点,从处理后的射频信号中提取有效特征。当前宽度学习方法对已经初步运用于通信辐射源个体识别领域,而其中特征节点和增强节点都是随机初始化,如何高效利用节点提取特征是一个待解决的问题。

为解决小样本通信辐射源个体分类中宽度神经网络的节点高效利用问题,本文提出基于注意力机制的宽度学习(Broad Learning Based on Attention Mechanism, AM-BL)识别方法,将注意力机制嵌入到宽度神经网络的特征节点与增强节点,利用其选择性关注输入数据中重要部分的特性,增强对输入数据的特征提取能力。实验表明,基于注意力机制的宽度学习算法对比宽度学习基线模型,通过增加注意力机制提高了网络的泛化性,在小样本条件下表现出更好的性能。

1 宽度学习与注意力机制

1.1 宽度学习

宽度学习方法是在传统的随机向量连接函数的基础上建立的^[15]。不同于传统加“深”的深度神经网络结构，宽度学习模型是向“宽”度扁平化扩展以增强神经网络的学习能力，并通过求解伪逆的方法获取网络隐藏层权重，避免了梯度消失或爆炸问题。宽度学习模型的一般架构如图 1 所示，第一层是输入层，第二层是作为隐藏层的特征层和增强层，第三层是输出层。输入数据通过特征节点和增强节点的映射拼接形成输入矩阵，连接输出层后计算矩阵伪逆确定网络的权值，实现宽度学习网络配置。




图 1 BL 系统模型

Fig.1 BL system model

1.1.1 特征节点

特征节点是输入层的线性变换，表示为

$$\mathbf{Z}_i = \phi_i(\mathbf{X}\mathbf{W}_{e_i} + \beta_{e_i}), i=1,2,\dots,n \quad (1)$$

其中 ϕ_i 表示第 i 个特征节点对应的激活函数， $\mathbf{X}$ 代表外部数据的输入， $\mathbf{W}_{e_i}$ 和 β_{e_i} 分别表示随机生成的初始权重及偏置。其中可调参数包括特征窗口数 n 和特征节点数 i ，这决定了特征矩阵的形状。此外，权重 $\mathbf{W}_{e_i}$ 和偏置 β_{e_i} 都是随机生成的，这导致了结果的随机性。

1.1.2 增强节点

利用增强节点的非线性变换进一步提高网络的拟合能力。理论上，只要存在无限的非线性变换节点，单层前馈网络就可以拟合任何问题。增强节点是为了进一步拓宽网络，可以表示为：

$$\mathbf{H}_j = \xi_j(\mathbf{Z}^n \mathbf{W}_{hj} + \beta_{hj}), j=1,2,\dots,m \quad (2)$$

ξ_j ， $\mathbf{W}_{hj}$ 和 β_{hj} 分别表示第 j 个增强节点对应的激活函数和随机生成的初始权重及偏置。其中参数 j 决定了增强矩阵的形状。

1.1.3 伪逆求解

在扁平网络中，伪逆是求解神经网络输出层权值的一种简便方法。通过求解伪逆的方法，宽度学习模型一次训练即可得出网络权重，避免了深度神经网络反向传播和梯度下降方面的相关运算，减少了训练过程的复杂度。求解伪逆可以认为是对线性方程的最小二乘估计，旨在以最小的训练误差达到输出权值：

$$\arg \min_{\mathbf{W}_m} (\|\mathbf{A}\mathbf{W} - \mathbf{Y}\|_{\sigma_1}^2 + \lambda \|\mathbf{W}\|_{\sigma_2}^2) \quad (3)$$

其中当 $\sigma_1 = \sigma_2 = v = u = 2$ 时，目标函数是典型的 l_2 正则化。其目标是 minimize 损失函数 $\|\mathbf{A}\mathbf{W} - \mathbf{Y}\|_2^2$ ，

并通过加入正则化项 $\lambda \|W\|_2^2$ 平衡模型复杂度与数据拟合能力之间的关系。 λ 表示对权值平方和 W 的进一步约束。

1.2 注意力机制

注意力机制^[16]是一种旨在自动识别并计算输入数据对输出决策的影响程度的模型结构，其核心思想来源于人类的选择性视觉和认知系统，它专注于关键信息，帮助模型更快地建立数据与标签的联系。这种机制尤其在处理序列数据时表现出其优势，可以帮助模型解决长距离依赖问题，并且有助于避免梯度消失或爆炸的问题。注意力机制的一个关键特点是它的灵活性，能够应用于多种不同的任务和领域。

本文提出的节点注意力模块通过计算节点的注意力分布对重要信息进行加强。节点注意力模块可以让宽度学习模型对输入特征图的每个节点进行不同程度的关注，通过不同节点的注意力权重来增强模型认为更重要的节点，抑制模型认为作用较小的节点，再重新将各个节点拼接在一起形成新的特征图，具体结构如图 2 所示。




图 2 节点注意力模块

Fig.2 Node attention module

设特征节点 Z_i 经过平均池化层和最大池化层，得到平均池化信息 $f_{avg} = [f_{1avg}, f_{2avg}, \dots, f_{navg}]$ 和最大池化信息 $f_{max} = [f_{1max}, f_{2max}, \dots, f_{nmax}]$ 。

$$f_{iavg} = \text{AveragePool}(Z_i) = \frac{1}{W} \sum_j Z_i(j, C), i = 1, \dots, n \quad (4)$$

$$f_{imax} = \text{MaxPool}(Z_i) = \max(F(1 \leq i \leq W, C)) \quad (5)$$

平均池化信息与最大池化信息分别乘上适配的系数得到适配当前数据的全局统计信息。并与随机生成的权重矩阵 W_a 相乘得到加权矩阵，对加权矩阵应用 Sigmoid 激活函数得到当前节点的注意力矩阵。

$$M_{ci} = \sigma((f_{iavg} + 2 * f_{imax}) \cdot W_a), i = 1, 2, \dots, n \quad (6)$$

2 结合注意力机制的宽度学习模型

AM-BL 模型在宽度神经网络提取特征的基础上，对其中的特征节点和增强节点加入注意力单元，利用注意力机制提取更重要的辐射源指纹特征。整体模型如图 3 所示。将原始 I/Q 数据作为宽度学习网络的输入经过随机权重映射、数据归一化和稀疏编码后生成网络的特征节点，将特征节点拼接整合再经过随机权重并激活增强生成非线性增强节点；然后对生成的特征节点和增强节点添加注意力模块，提高各节点对特征的表达能能力；最后，将添加了注意力模块的特征节点和增强节点直接连接到输出端，对应的网络权重可以通过快速的伪逆计算得出。




图3 AM-BL 系统模型

Fig.3 AM-BL system model

以 N 组辐射源 I/Q 数据样本构成原始输入矩阵 $\mathbf{X}$ ，即： $\mathbf{X} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N)^T$ 。则由初始输入矩阵 $\mathbf{X}$ 通过公式 1 到第 i 个节点特征矩阵 $\mathbf{Z}_i$ 的映射为 $\mathbf{Z}^n = [\mathbf{Z}_1, \mathbf{Z}_2, \dots, \mathbf{Z}_n]$ 。

由特征矩阵 $\mathbf{Z}^n$ 通过公式 2 到增强节点的映射 $\mathbf{H}^m = [\mathbf{H}_1, \mathbf{H}_2, \dots, \mathbf{H}_m]$ 。

在节点注意力模块中，分别以特征矩阵 $\mathbf{Z}^n$ 和增强矩阵 $\mathbf{H}^m$ 为输入，由公式 4-6 分别计算特征矩阵和增强矩阵的注意力矩阵 $\mathbf{M}_{cn}$ 和 $\mathbf{M}_{cm}$ 。

再将原始矩阵与注意力矩阵相乘得到新的特征矩阵 $\mathbf{Z}^{n'}$ ， $\mathbf{H}^{m'}$ 。

$$\mathbf{Z}^{n'} = \mathbf{Z}^n \cdot \mathbf{M}_{cn} \quad (7)$$

$$\mathbf{H}^{m'} = \mathbf{H}^m \cdot \mathbf{M}_{cm} \quad (8)$$

将经过节点注意力模块优化后的特征矩阵和增强矩阵拼接起来得到新的输入矩阵 $\mathbf{A} = [\mathbf{Z}^{n'} | \mathbf{H}^{m'}]$ 。

则 BL 的输出结果 $\mathbf{Y}$ 为：

$$\mathbf{Y} = [\mathbf{Z}^n | \mathbf{H}^m] \mathbf{W}^m \quad (9)$$

其中 $\mathbf{W}^m = [\mathbf{Z}^n | \mathbf{H}^m]^+ \mathbf{Y} = \mathbf{A}^+ \mathbf{Y}$ ，是神经网络的连接权重，可以通过公式 3 近似计算得到：

$$\mathbf{W}^m = (\lambda \mathbf{I} + \mathbf{A} \mathbf{A}^T)^{-1} \mathbf{A}^T \mathbf{Y} \quad (10)$$

其中当 $\lambda \rightarrow 0$ 时，该问题退化为最小二乘问题，并导致解为原伪逆。得到 AM-BL 网络的权值：

$$\mathbf{W}^m = \mathbf{A}^+ \mathbf{Y} = \lim_{\lambda \rightarrow 0} (\lambda \mathbf{I} + \mathbf{A} \mathbf{A}^T)^{-1} \mathbf{A}^T \mathbf{Y} \quad (11)$$

对于未知标签的辐射源数据 $\mathbf{X}'$ ，经过相应的输入变换后得到输入矩阵 $\mathbf{A}'$ ，则对应的识别结果为 $\mathbf{Y} = \mathbf{A}' \mathbf{W}^m$ 。

3 实验结果与分析

3.1 实验平台和数据准备

实验所用的硬件平台 CPU 为 Intel(R) Core(TM) i7-12700KF, GPU 为 NVIDIA GeForce RTX 3070 Ti, 开发环境为基于 Python3.9 的 Pytorch 深度学习框架。

为了验证提出的辐射源个体识别方法有效性, 本文对网上公开的辐射源个体识别数据集^[17]进行实验并与深度学习残差网络进行比较。实验采用的数据集为开源 ADS-B 数据集, 其信号采集器由实时频谱仪 SM200B 和 1090-MHz 全向天线组成。由于 ADS-B 信号数据块包含飞机识别码、位置、高度、速度等。因此, 对数据块进行解调即可得到样本类别。此外, 预处理后的 ADS-B 信号作为 IQ 样本, 信号类别是 10 个辐射源个体。具体参数如表 1 所示。本文实验均采用 10, 20,30,50 到 100 个训练样本模拟样本从少到多的情景, 测试样本数量为 100 个。实验结果均为 50 次蒙特卡洛实验后的均值。

表 1 数据集信号参数

Table 1 Dataset signal parameters	
参数	参数值
信号载频/MHz	1090
调制方式	PPM 脉冲位置调制
采样带宽/MHz	10
采样率/MHz	50
信号增益/dB	30
单个样本信号长度	4800

3.2 注意力机制对特征提取能力提升评估

为说明注意力机制对宽度学习特征提取能力的提升, 本文通过对比使用注意力机制前后 Fisher 准则结果来衡量特征提取能力的优劣。Fisher 准则通常定义为类间离差阵与类内离差

类内离差阵反映的是类别内部的差异程度, 计算方法如下:

$$S_w^j = \frac{1}{n_j} \sum_{i=1}^{n_j} (\bar{x}_i^{(j)} - \bar{m}_j)(\bar{x}_i^{(j)} - \bar{m}_j)' \quad (12)$$

式中, $\bar{m}_j$ 为第 j 类样本的均值矢量, 即 $\bar{m}_j = \frac{1}{n_j} \sum_{i=1}^{n_j} \bar{x}_i(j)$ 。 n_j 表示第 j 类样本的样本数。 c 表示

待分类的类别数, 即需要分成 c 个类别。

类间离差阵则表示不同类别间的平均差异程度。计算方法如下:

$$S_B = \sum_{j=1}^c \frac{n_j}{N} (\bar{m}_j - \bar{m})(\bar{m}_j - \bar{m})' \quad (13)$$

式中, $\bar{m} = \frac{1}{N} \sum_{i=1}^N \bar{x}_i$ 为所有待分类样本的均值矢量。 N 表示样本总数。

最终得到 Fisher 准则结果:

$$J_1 = Tr[S_w^{-1} S_B] \quad (14)$$

对不同训练样本数量添加节点注意力模块前后 Fisher 准则实验结果如表 2 所示, 添加节点注意力模块前后 Fisher 准则值分别为 J_{11} 、 J_{12} 。

表 2 添加节点注意力模块前后 Fisher 准则值对比

Table 2 Comparison of Fisher criterion values before and after adding the node attention module

	10	20	50	100
J_{11}	51.42	120.56	318.18	561.42
J_{12}	52.70	125.21	367.79	828.15

实验表明,在不同样本数量条件下,添加节点注意力模块后 Fisher 准则值上升,提取的特征类别可分性增加。

3.3 不同参数设置下性能对比

为验证本实验设置参数的有效性,通过控制变量法在基线模型上选取识别性能良好的参数。

3.3.1 不同节点或窗口个数对识别准确率的影响

选取正则化系数 λ 为 10^{-6} ,对比在不同训练样本数量下节点或窗口个数对训练精度的影响。结果如图 4-图 6 所示,当节点或窗口个数过小时,网络无法完全提取表达电台的指纹特征,识别准确率较低;当节点或窗口个数逐渐变大时,识别准确率逐渐提高;但当节点或窗口个数过大时,网络会出现过拟合现象,导致识别准确率下降,且增强节点个数过大时,网络运算复杂度增加,训练时间变长。另外,当训练样本数量较少时,指纹特征对节点或窗口个数的变化更敏感,其识别准确率在不同节点或窗口个数下变化较为明显。当样本数量在 50 个以上时,网络能够较好对辐射源个体进行识别,其识别精度变化比较平稳。综合实验结果来看,选取特征节点个数 N_1 为 8、特征节点的窗口个数 N_2 为 8、增强节点个数 N_3 为 3000 作为固定参数进行后续实验。




图 4 不同特征节点个数准确率对比

Fig.4 Comparison of accuracy under different number of feature nodes




图 5 不同特征窗口个数准确率对比

Fig.5 Comparison of accuracy under different feature windows




图 6 不同增强节点个数准确率对比

Fig.6 Comparison of accuracy under different number of enhancement nodes

3.3.2 不同正则化系数对识别准确率的影响

对比在不同训练样本数量下正则化系数 λ 对训练精度的影响，取 10 的负指数幂作为横坐标。结果如图 7 所示， λ 从 10^{-1} 逐渐向 10^{-6} 减小时，网络对个体电台的识别准确率逐渐上升。随着 λ 进一步减小，识别准确率趋于稳定。在减小到 10^{-11} 时网络识别准确率开始急剧下降。分析其原因， λ 变小时，所求得解更加贴近原伪逆，数据拟合能力更强，网络识别准确率随之提升。当 λ 小到一定程度后，正则化项对伪逆求解的影响几乎没有，网络过拟合严重，识别准确率随之下降。综合实验结果来看，选取 λ 为 10^{-6} 作为固定参数进行后续实验。




图 7 不同正则化系数准确率对比

Fig.7 Comparison of accuracy under different regularization coefficients

为了验证本文提出的 AM-BL 方法与宽度学习基线模型性能差异，后续实验结果中 BL、文献[14]中的 SFEBLN 与 AM-BL 方法均采用最终得到的表 3 所示参数，SFEBLN 新增的内部信号节点参数与原文不变。

表 3 模型主要参数设置

Table 3 Set the main parameters of the model

参数	参数值
特征节点个数 N1	8
特征节点的窗口个数 N2	8
增强节点个数 N3	3000
正则化系数 λ	10^{-6}

3.4 不同训练样本数量条件下识别结果

为说明本文方法的性能优势，将本文方法与文献[16]中的 ResNet18 模型、文献[18]中的 Transformer 模型和文献[14]中的 SFEBLN 模型和宽度学习基线模型的识别精度和推理识别总体时间

进行对比。深度学习模型架构与原文不变，只改变输入输出接口，ResNet18 模型和 Transformer 模型超参数设置为 Adam 优化方法，学习速率 0.0001，丢弃率为 0.1，训练迭代次数为 50。ResNet18 模型批处理大小为 32，Transformer 模型批处理大小为 8，皆已达到本实验所用硬件平台极限。5 种方法各进行 50 次蒙特卡洛实验取平均值。不同方法的识别准确率和推理识别总体时间结果如表 4 所示。

实验表明，在少量训练样本条件下，辐射源个体识别模型性能皆有所下降，而本文模型在不同训练样本数量条件下较其他模型保持了更好的识别结果，当训练样本数量为 100 个时，AM-BL 模型可达到 97.9%的识别准确率；同时，ResNet18 网络随着训练样本增多，识别准确率也在上升，当训练集完备时性能是有可能超越宽度学习网络的。在与 BL 模型的消融实验对比中，加入注意力模块后，辐射源个体识别结果整体提高了 1%-2%。


总体来看，宽度学习模型通过映射和增强特征的方式对输入数据进行预处理，提取了有用的特征信息，并由于其简单的结构减轻了模型在少量样本时的过拟合现象，在识别准确率上优于深度学习模型；而且因为宽度学习避免了深度网络中复杂的层与层之间的连接和大量超参数的调整，实际耗费的训练时间远少于 ResNet18 和 Transformer 网络。同时，本文提出的 AM-BL 模型在不同样本数量条件下识别准确率都优于 BL 基线模型，其通过对每个节点上的特征矩阵施加不同的权重，来确定不同节点对于最终任务的贡献度。这种权重分配有助于模型更加关注与任务紧密相关的特征，同时抑制那些不重要的信息，在不显著增加计算量的情况下提高了网络的识别精度。

表 4 不同训练样本数目的识别准确率和推理识别总体时间


Table 4 The recognition accuracy and the overall inference recognition time for different training sample numbers

	10		20		30		50		100	
	准确率	时间	准确率	时间	准确率	时间	准确率	时间	准确率	时间
	(%)	(s)	(%)	(s)	(%)	(s)	(%)	(s)	(%)	(s)
ResNet18	65.6	13.84	73.5	19.58	80.7	24.65	87.1	34.25	91.3	53.27
Transformer	25.7	5252.33	27.23	6208.00	28.43	6957.01	39.7	8565.78	76.6	20507.14
BL	68.0	0.82	84.3	0.82	90.3	0.85	95.3	0.89	97.3	1.01
SFEBLN	14.3	0.80	57.5	0.87	83.5	0.89	89.9	0.94	91.9	1.05
AM-BL	69.6	0.92	85.9	0.93	91.5	0.96	95.9	1.00	97.9	1.10

另外，为了避免个体偏差对实验结果的影响，通过混淆矩阵来进一步验证实验结果。其中 BL 算法和 AM-BL 算法在训练集样本数目为 100 时的混淆矩阵结果如图 8 所示。从混淆矩阵可以看出，本文提出的 AM-BL 方法对每类样本的识别效果不低于 BL 基线模型，在整体识别率上有所提高，有效增加了 BL 基线模型的识别准确率。



(a) BL Confusion matrix



(b) AM-BL Confusion matrix

图 8 混淆矩阵结果

Fig.8 Confusion matrix results

4 结论

针对小样本条件下的辐射源个体识别问题，本文提出融合注意力机制和宽度学习构建浅层神经网络的通信辐射源个体识别方法。通过构建节点注意力模块，并根据宽度学习方法提取特征的重要性对其进行加权处理，得到辐射源指纹特征的更好表示。结果表明，小样本条件对辐射源个体识别的效果有较大影响，而本文方法相对残差网络和 BL 基线模型在不同样本数量条件下都产生了更好的效果。通过宽度学习简化模型结构的方法能够减轻小样本条件带来的过拟合影响，加入注意力机制后有助于分类特征提取。

参考文献

- [1] 胡苏, 马上, 林迪, 等. 基于射频指纹技术的卫星信号个体识别方法[J]. 信息对抗技术, 2022, 第 1 卷(1): 55-61.
- [2] 刘志文, 陈旗, 郑恒权, 等. 基于特征融合的通信辐射源个体识别[J]. 数据采集与处理, 2022, 37(6): 1280-1287.
- [3] WU Q, FERES C, KUZMENKO D, et al. Deep learning based RF fingerprinting for device identification and wireless security[J]. Electronics Letters, 2018, 54(24): 1405-1407.
- [4] GONG J L, XIAO D, YING K L. Un-supervised specific emitter identification method using radiofrequency fingerprint embedded InfoGAN[J]. IEEE Transactions on Information Forensics and Security, 2020, 15: 2898-2913.
- [5] 徐惠灵, 尚政国, 董胜波, 等. 面向深度神经网络应用的小样本学习技术研究[J]. 南京航空航天大学学报, 2022, 第 54 卷(201): 80-86.
- [6] Nakamura A, Harada T. Revisiting fine-tuning for few-shot learning[EB/OL]. <https://arxiv.org/abs/1910.00216>, 2024-04-19.
- [7] WANG C, FU X, WANG Y, et al. Few-shot specific emitter identification via hybrid data augmentation and deep metric learning[EB/OL]. <https://arxiv.org/abs/2212.00252>, 2024-04-19.
- [8] WANG Y, GUI G, LIN Y, et al. Few-shot specific emitter identification via deep metric ensemble learning[J]. IEEE Internet of Things Journal, 2022, Vol.9(24): 24980-24994.
- [9] XIE C X, ZHANG L M, ZHONG Z G. Few-Shot Specific Emitter Identification Based on Variational Mode Decomposition and Meta-Learning[J]. Wireless Communications and Mobile Computing, 2022, 2022: 1-9.
- [10] Chen C L, LIU Z L. Broad learning system: an effective and efficient incremental learning system without the need for deep architecture[J]. IEEE Trans on Neural Networks and Learning Systems, 2017, 28(12): 3056-3066.

- Systems, 2018, 29(1): 10-24.
- [11] Chen C L, LIU Z L. Broad learning system: a new learning paradigm and system without going deep[C]//Proc of the 32nd Youth Academic Annual Conference of Chinese Association of Automation. Piscataway, NJ: IEEE Press, 2017: 1271-1276.
- [12] XU Z W, HAN G J, LIU L, et al. A Lightweight Specific Emitter Identification Model for I-IoT Devices Based on Adaptive Broad Learning[J]. IEEE Transactions on Industrial Informatic-s, 2023, Vol.19(5): 7066-7075.
- [13] ZHANG Y, GONG B, WANG Q. BL-identification: A device fingerprint classification mechanism based on broad learning for internet of things[J]. Digital Communications and Networks, 2024 Vol.10(3): 728-739.
- [14] ZHANG Y B, PENG Y, SUN J L, et al. GPU-Free Specific Emitter Identification Using Signal Feature Embedded Broad Learning[J]. IEEE Internet of Things Journal, 2023, Vol.10(14): 13028-13039.
- [15] YOH H P, GWANG H P, DEJAN J S. Learning and generalization characteristics of the random vector functional-link net[J]. Neurocomputing, 1994, Vol.6(2): 163-180.
- [16] 曲凌志, 杨俊安, 刘辉, 等. 嵌入注意力机制的通信辐射源个体识别方法[J]. 系统工程与电子技术, 2022, 第44卷(1): 20-27.
- [17] TU Y, LIN Y, ZHA H R, et al. Large-scale real-world radio signal recognition with deep learning[J]. Chinese Journal of Aeronautics, 2022, 35(9): 35-48.
- [18] ZHANG Z M, LEI Z Y, OMURA M, et al. Dendritic Learning-Incorporated Vision Transformer for Image Recognition[J]. IEEE/CAA Journal of Automatica Sinica, 2024, 11(2): 539-541.

作者简介:



陈宇鹏(1997-), 男, 硕士研究生, 研究方向: 通信对抗、深度学习。E-mail: 1090145783@qq.com



刘辉(1983-), 男, 副教授, 博士, 研究方向: 通信对抗, 智能信息处理等。E-mail: liuhui17c@nudt.edu.cn



任高星(1982-), 男, 助理工程师, 硕士, 研究方向: 通信对抗。E-mail: 710231091@qq.com



杨俊安(1965-), 男, 教授, 博士, 研究方向: 信号处理、智能计算等。E-mail: yangjunan@ustc.edu